PATENT ABSTRACTS OF JAPAN

(11) Publication number:

11-066225

(43) Date of publication of application: 09.03.1999

(51) Int. CI.

G06K 9/00

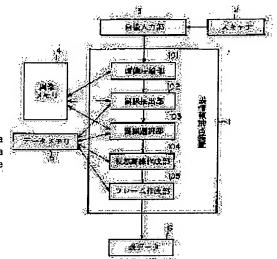
(21) Application number : **09-227691** (22) Date of filing : **25.08.1997** (71) Applicant: RICOH CO LTD (72) Inventor: YAMAAI TOSHIFUMI

(54) DEVICE AND METHOD FOR TABLE INFORMATION EXTRACTION AND RECORD MEDIUM

(57) Abstract:

PROBLEM TO BE SOLVED: To precisely extract table information by preventing a ruled line which is not necessary for structure analysis of a table from being extracted, meanwhile compensating a deficient ruled line.

SOLUTION: Binary image information is inputted to an image compression part 101 via a scanner 2 and an image input part 3 and recorded in an image memory 4, and image information which is needed for table information extraction is aread out properly. After the image information inputted to the table information extraction device 1 has been compressed by the image compression part 101, a ruled-line selection part 103 makes the choice of whether or not a ruled line needs to be corrected, a virtual ruled-line generation part 104 generates a virtual ruled line, and a frame generation part 105 generates a necessary frame. Further, a ruled-line extraction part 102, the ruled-line selection part 103, and the virtual ruled-line generation part 104 operate, while exchanging data with a data memory 5. Then a ruled line is extracted from a table area on an image and while an unnecessary ruled line is removed, a deficient ruled line is complemented to generate the frame.



LEGAL STATUS

[Date of request for examination]

[Date of sending the examiner's decision of rejection]

[Kind of final disposal of application other than the examiner's decision of rejection or application converted registration]

[Date of final disposal for application]

[Patent number]

[Date of registration]

[Number of appeal against examiner's decision of rejection]

[Date of requesting appeal against examiner's decision of rejection]

[Date of extinction of right]

Copyright (C): 1998, 2000 Japan Patent Office

(19)日本国特許庁 (JP)

(12) 公開特許公報(A)

(11)特許出願公開番号

特開平11-66225

(43)公開日 平成11年(1999)3月9日

(51) Int.Cl.⁶

識別記号

FΙ

G06K 9/00

G06K 9/00

Ρ

審査請求 未請求 請求項の数9 OL (全 8 頁)

(21)出願番号

(22)出願日

特願平9-227691

平成9年(1997)8月25日

(71)出顧人 000006747

株式会社リコー

東京都大田区中馬込1丁目3番6号

(72)発明者 山合 敏文

東京都大田区中馬込1丁目3番6号 株式

会社リコー内

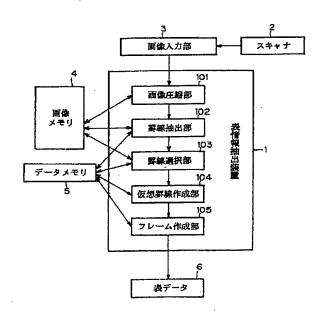
(74)代理人 弁理士 高野 明近 (外1名)

(54) 【発明の名称】 表情報抽出装置及び方法並びに記録媒体

(57)【要約】

【課題】 画像上の表領域からの罫線の誤抽出を防止するとともに、仮想罫線により罫線を補完し、表の構造解析に不要な仮想罫線を抽出しないようにするか作成しないようにして、精度よく画像上の表領域を認識する。

【解決手段】 表情報抽出装置は、罫線か否か判断して 罫線情報を抽出する罫線抽出部と、表の構造解析に不要 な罫線を除外する罫線選択部と、抽出された罫線からフ レームを構成するフレーム作成部、及びフレーム作成時 に不足する罫線を補う仮想罫線を作成するとともに不要 な罫線を作成しない仮想罫線作成部を持つ。



1

【特許請求の範囲】

【請求項1】 画像上の表領域から罫線情報を抽出する 罫線抽出部、不要な罫線を除外する罫線選択部、抽出さ れた罫線からフレームを構成するフレーム作成部、及び フレームを作成に不足する罫線を補う仮想罫線を作成す る仮想罫線作成部、とからなることを特徴とする表情報 抽出装置。

【請求項2】 請求項1記載の表情報抽出装置において、前記罫線抽出部は、長い黒画素成分を統合していくことで罫線を抽出するものであって、同一方向にある分 10 断された罫線間の画像情報から、前記分断された罫線がかすれで分断されているのかどうかを判定し、かすれと判定した場合は両罫線を一つの罫線として抽出することを特徴とする表情報抽出装置。

【請求項3】 請求項1記載の表情報抽出装置において、前記罫線選択部は、抽出された罫線が文字矩型に包合されている場合は、その罫線を罫線でないと判定し、表を構成する罫線からは除外するように罫線選択をすることを特徴とする表情報抽出装置。

【請求項4】 請求項1 記載の表情報抽出装置において、前記罫線選択部は、水平罫線と垂直罫線が互いに一度も交わらない、または端同士が近接することのない罫線を抽出し、それらを表を構成する罫線から除外するように罫線選択をすることを特徴とする表情報抽出装置。

【請求項5】 請求項1記載の表情報抽出装置において、前記仮想罫線作成部は、水平・垂直の罫線で、端部が別の罫線と交わらないまたは端同士が近接しない罫線の端部から、該罫線に直交する方向の仮想罫線をそれと最初に交差する罫線または端部に近接する罫線まで引くことで仮想罫線を作成することを特徴とする表情報抽出 30 装置。

【請求項6】 請求項5記載の表情報抽出装置において、前記仮想罫線作成部は、水平・垂直の罫線で、端部が別の罫線と交わらないまたは端同士が近接しない罫線の端部から、表の指定された領域の端まで水平、垂直の仮想罫線を引き、その後、前記仮想罫線同士が交わっている点を端点として領域の端までの前記仮想罫線を消去することを特徴とする表情報抽出装置。

【請求項7】 請求項5記載の表情報抽出装置において、水平・垂直の罫線で、端部が別の罫線と交わらない 40 または端同士が近接しない罫線のうち、表の指定された領域の端に最も近接した罫線の端部から該領域の端には仮想罫線を引かないことを特徴とする表情報抽出装置。

【請求項8】 請求項1~7のいずれかに記載の表情報抽出装置で、前記表情報抽出をソフトウエアで実現することを特徴とする表情報抽出方法。

【請求項9】 請求項8記載の表情報抽出方法を実現するプログラムを記録したコンピュータ読取り可能な記録 媒体。

【発明の詳細な説明】

2

[0001]

【発明の属する技術分野】本発明は、文字認識装置(OCR)の前処理部に関するものであって、特に文字認識装置において、入力された文書や帳票などの画像例えば2値画像中の表領域を認識する装置及び表情報抽出方法並びに同方法を実現するプログラムを記録したコンピュータ読取り可能な記録媒体に関するものである。

[0002]

【従来の技術】文字認識装置において文書画像を処理する場合、画像を文字領域、写真や図などのイメージ領域、表領域などに分割してそれぞれ別の処理を行なうことが多い。このうち表領域に関しては、罫線の位置座標を用いて表中の各枠内の画像を切り出し文字を認識する方法が採られている。例えば特開平2-264386号公報においては、従来の各枠が四方とも罫線によって囲まれているものだけでなく、両脇に罫線が存在しない表についても表領域としての処理ができる方法が提案されている。しかしながら、この方法では前記公報記載の単純な表であれば問題なく処理できるものの、外側の形が20多角形である表や仮想罫線の必要のない表を処理すると不必要なところに仮想罫線を誤抽出し、表の構造を解析する上で障害となる場合が出るという欠点がある。

[0003]

【発明が解決しようとする課題】本発明の課題は前記の 欠点を解消することであって、請求項1の発明の課題 は、表の構造解析に不必要な罫線の抽出を防止し、他: 方、不足する罫線を補うことにより、精度よく表情報を、 抽出することである。請求項2の発明の課題は、請求項 1の発明の課題に加え更にかすれた罫線を抽出すること** である。請求項3の発明の課題は、請求項1の発明の課 題に加え更に誤って文字を罫線と誤認して抽出すること を防止することである。請求項4の発明の課題は、請求 項1の発明の課題に加え更に表の構成解析に不要な罫線 を抽出して除外できるようにすることである。 請求項5 の発明の課題は、請求項1の発明の課題に加え更に表抽 出に必要な仮想罫線を作成することである。請求項6及 び請求項7の発明の課題は、請求項5の発明の課題に加 え更に表抽出に必要な仮想罫線を容易に作成することで ある。請求項8の発明の課題は、表情報の抽出をソフト ウエアで実現することである。請求項9の発明の課題 は、請求項8のソフトウエアを記録した媒体を提供する ことである。

[0004]

【課題を解決するための手段】請求項1の発明は、画像上の表領域から罫線情報を抽出する罫線抽出部、不要な 罫線を除外する罫線選択部、抽出された罫線からフレームを構成するフレーム作成部、及びフレームを作成に不 足する罫線を補う仮想罫線を作成する仮想罫線作成部、 とからなることを特徴とする表情報抽出装置である。

【0005】請求項2の発明は、請求項1記載の表情報

抽出装置において、前記罫線抽出部は、長い黒画素成分を統合していくことで罫線を抽出するものであって、同一方向にある分断された罫線間の画像情報から、前記分断された罫線がかすれで分断されているのかどうかを判定し、かすれと判定した場合は両罫線を一つの罫線として抽出することを特徴とする表情報抽出装置である。

【0006】請求項3の発明は、請求項1記載の表情報抽出装置において、前記罫線選択部は、抽出された罫線が文字矩型に包合されている場合は、その罫線を罫線でないと判定し、表を構成する罫線からは除外するように 10 罫線選択をすることを特徴とする表情報抽出装置である

【0007】請求項4の発明は、請求項1記載の表情報抽出装置において、前記罫線選択部は、水平罫線と垂直 罫線が互いに一度も交わらない、または端同士が近接することのない罫線を抽出し、それらを表を構成する罫線から除外するように罫線選択をすることを特徴とする表情報抽出装置である。

【0008】請求項5の発明は、請求項1記載の表情報抽出装置において、前記仮想罫線作成部は、水平・垂直 20の罫線で、端部が別の罫線と交わらないまたは端同士が近接しない罫線の端部から、該罫線に直交する方向の仮想罫線をそれと最初に交差する罫線または端部に近接する罫線まで引くことで仮想罫線を作成することを特徴とする表情報抽出装置である。

【0009】請求項6の発明は、請求項5記載の表情報抽出装置において、前記仮想罫線作成部は、水平・垂直の罫線で、端部が別の罫線と交わらないまたは端同士が近接しない罫線の端部から、表の指定された領域の端まで水平、垂直の仮想罫線を引き、その後、前記仮想罫線同士が交わっている点を端点として領域の端までの前記仮想罫線を消去することを特徴とする表情報抽出装置である。

【0010】請求項7の発明は、請求項5記載の表情報抽出装置において、水平・垂直の罫線で、端部が別の罫線と交わらないまたは端同士が近接しない罫線のうち、表の指定された領域の端に最も近接した罫線の端部から該領域の端には仮想罫線を引かないことを特徴とする表情報抽出装置である。

【0011】請求項8の発明は、請求項1~7のいずれ 40かに記載の表情報抽出装置で、前記表情報抽出をソフトウエアで実現することを特徴とする表情報抽出方法である。

【0012】請求項9の発明は、請求項8記載の表情報抽出方法を実現するプログラムを記録したコンピュータ 読取り可能な記録媒体である。

[0013]

【発明の実施の形態】本発明の表情報抽出装置を図1を 参考にして説明する。本願発明の表情報抽出装置1は、 画像圧縮部101、罫線抽出部102、罫線選択部10 4

3、仮想罫線作成部104及びフレーム作成部105から成っており、画像圧縮部101にはスキャナ2、画像入力部3を介して2値画像情報が入力される。また、表情報抽出装置1は、画像入力部3からの前記画像情報を画像圧縮部101を介して画像メモリ4に記録し、表情報抽出に必要な画像情報を適宜読み出すこともできる。

【0014】表情報抽出装置に入力された前記画像情報は画像圧縮部101で圧縮された後、罫線抽出部102で入力画像中の罫線が判別抽出される。罫線選択部103では補正が必要な罫線かあるいは不必要な罫線かの選択が行われ、更に、仮想罫線作成部104は仮想罫線を形成し、フレーム作成部105において必要なフレームが形成される。なお、罫線抽出部102、罫線選択部103、仮想罫線作成部104及びフレーム作成部105はそれぞれデータメモリ5との間でデータの交換を行いながら前記の作業を行う。

【0015】次に、図2を参考に、本発明の表情報抽出装置の動作について説明する。本表情報抽出装置に2値画像が入力されると(S101)、まず、前記入力画像の表領域の認識又はユーザによる表領域の指定が行われ(S102)、それに従って、X方向の罫線抽出(S103)、Y方向の罫線抽出が行われる(S104)。さらにX方向及びY方向の罫線を補完し(S105,106)、しかる後に不要な罫線を除外し(S107)、更に必要な仮想罫線を作成し(S108)、表構造を抽出(S109)して一連の動作を終了する。

【0016】画像圧縮部101はデータとして与えられた画像情報を所定の圧縮率でOR圧縮を行う。この画像圧縮部101は必ずしも必要でないが、画像圧縮を行うと、例えばOR圧縮であれば、処理するデータ量の削減により高速化が図れ、また圧縮率未満のドットのかすれは問題にならなくなる。但し、得られる座標情報などは実際の画像からみて圧縮率程度の誤差を含み、低解像度画像では微妙に処理に影響することが考えられる。

【0017】罫線抽出部102は長い黒画素成分のつな がりをみてそれを外接矩型で囲む処理を行う。また、黒 画素成分の長いランをみるために、水平、垂直で走査方 向を変えて罫線抽出を行うが、その他の罫線を補完する 処理もここで行うことができる。図3は、その実施態様 を示すものであって、罫線の分断によって罫線がかすれ た場合の例を示している。罫線がかすれた場合には、分 断された部分を挟んで対向した罫線が見つかるととも に、前記部分には図示のかすれているような画素、つま り"かすれ矩型"が見つかる。この場合これらを統合す ることで、1本の罫線とすることができる。つまり、よ り詳しく説明すれば罫線抽出部102は、長い黒画素成 分を統合していくことで罫線を抽出し、水平、または垂 直の同一方向にある罫線の座標値からかすれで分断され ている罫線かどうかをその距離、罫線と罫線の間にある 画素の集まり罫線の密度などの情報から判定し、同一罫 線のかすれと判定された場合は統合して、一つの罫線と して扱うものである。

【0018】また、罫線抽出部102はかすれの位置に 画素を見つけるだけでなく、積極的に補完することもで きる。次にその点を図4を参考に説明する。図4は、罫 線にA、B、Cの3つの「切れ」がある場合を示してい る。この場合において、補完したい「切れ」はA, Bで あり、Cは補完を必要としないものであるとする。この 実施形様においては、対象とする罫線と直交する罫線の 密度と直行する罫線からの出っ張り具合を見て「切れ」 が補完を必要とするものなのか否かを判別している。ま た、その際に、かすれている罫線と直交する方向の罫線 がどの程度の間隔で並んでいるかを調べ、最大でどのく らいの間隔を補完をすべきかの情報を得る。罫線抽出部 102はこれを行うことで、例えば図中Cのように本来 罫線のない部分に罫線を間違って作る誤動作を防ぐこと、 ができる。

【0019】本発明の罫線選択部103の一実施態様に よれば、罫線選択部103は本来罫線ではないのに罫線 として抽出されてしまったものを除く処理を行うことが 20 できる。例えば、文字自体が大きい場合は長いランが検 出されるので、その文字から罫線を抽出することがあり 得る。その場合、罫線選択部103は、抽出されたもの が罫線か否かを判断する。罫線でないと判定した場合 は、その罫線を表を構成する罫線からは除外する方法で 罫線選択することができる。これを図5を参考にして説 明すると、大きなフォントで書いある文字中には長いラ ンがあるので、そこから罫線7を抽出してしまうことが ある。その場合短いランを含めて矩型抽出を行うと図の 外枠の様な外接矩型8が見つかる。そして、その外接矩 型8の内部の情報(画素の数、長いランの数、矩型の絶 対値、縦横比など)から前記外接矩型が文字矩型である か否かを判定し、文字矩型であると判定した場合、その 文字矩型に包含される罫線7を除外することで無関係な 罫線を取り除くことができる。この方法は圧縮された画 像でより高い効果が望める。

【0020】本発明の罫線選択部103の他の実施態様 によれば、罫線選択部103は、水平罫線と垂直罫線が 互いに一度も交わらない、または端同士が近接すること のない罫線を抽出し、それらを表を構成する罫線から除 40 外する方法で罫線選択をすることができる。即ち、罫線 選択部103は、他の罫線と全く交わっていないか近接 していない罫線をみつける。この近接というのは、かす れなどで、ちょうど角に当たる部分が欠けた罫線を想定 している。この条件にあてはまる罫線は、文字矩型と判 断される矩型に包含されず、従って罫線でないと判断さ れないから、表を構成する罫線から除外されないもので あるが、表構造解析には不要な罫線として除外しておく と、次過程で行う仮想罫線の作成に影響が起きにくくな る。例えば図6に示すように見た目が完全に表であるも 50 または端同士が近接しない罫線のうち、表の指定された

のだけでなく、定型、不定型のフォーマットのものにも 適用でき、図中、宙に浮いているように見える2本の罫 線しは表の構造解析には使わなくてもよく、むしろ後過 程の仮想罫線作成処理に不都合が生じることになるか ら、表の構造を抽出する際に除外することができる。

【0021】次に、本発明の仮想罫線作成部104につ いて、図7を参考にして説明する。この仮想罫線作成部 104では、水平、垂直の罫線で端部が別方向の罫線と 交わらない、または端同士が近接しない端部のみを抽出 10 し、抽出した罫線端部の、垂直罫線であるならばY座標 (Y1)、水平罫線であるならばX座標(X1)に注目 し、それぞれY=Y1、X=X1という仮想罫線を、最一 初に交差するまたは端点に近接する罫線まで引くこと で、仮想罫線を作成することができる。つまり、表の構 造を得るのに、不要な罫線が除外されている状態で、2: カ所ある罫線の端部に注目し、この端部がその罫線と直 交する方向の罫線のいずれかと近接しているかどうかを 調べる。ここでいう近接は既に説明したとおり、角が欠 落した場合を想定してのものである。直交する方向の罫 線と端部が接しているか又は近接している罫線について は、この仮想罫線作成は無関係である。直交する方向の 罫線と近接又は接していない端部がみつかった場合に は、その端部に直交する罫線を仮想的に作る。例えば、 図7に示すように、垂直罫線の端部にX=X1である直 線を仮想罫線として作る。仮想罫線作成範囲は、最初に 交差または端点に近接する罫線までである。

【0022】この処理を行うことで、表の内部の状態に ついては本来必要である部分には罫線が全て引かれたも のとして、処理することができる。実際の処理では、罫 線情報は傾きなどで、微妙な位置関係になることと、罫 線と罫線の間隔が短い場合などには、前記処理が繰り返 し行われることにより本来1本の長い線であるはずのも のが、短いジグザグな線の連続になってしまうので、こ れを補正する処理手段を設けることが望ましい。または 処理を行う前に、認識した線のベクトル化を図ると、さ らに障害を起こす可能性は小さくなる。

【0023】仮想罫線を引く場合に、交差するまたは端。 点に近接する罫線がなかった場合には、表と指定された 領域の端まで罫線を引き、水平、垂直の仮想罫線を引き 終わった段階で、仮想罫線同士の交わっている点を端点 として、仮想罫線を短くすることができる。つまり、図 8 (A) 、(B) に示すように表と指定した領域の端ま で線を作っておき、水平、垂直と処理をしたあとで、仮 想罫線の交差した部分から端までの罫線を消去をしない ものとして処理する(図8(C))ことで、例えば、図 9のような表を処理することができる。更に、図10の ような仮想罫線を直接形成するようにして処理を単純に することもできる。即ち、仮想罫線を引く場合におい て、水平・垂直の罫線で、端部が別の罫線と交わらない

7

領域の端に最も近接した罫線の端部から該領域の端には 罫線を引かないようにすることもできる。

【0024】次に、本発明の罫線抽出をソフトウェアによって実現する場合について説明する。図11に本発明の方法を実現するためのコンピュータシステムの一例を示している。このシステムは、CPU、メモリ、表示装置、ハードディスク、キーボード、CD-ROMドライブ、スキャナなどからなっている。CD-ROMなどのコンピュータ読み取り可能な記録媒体には、本発明の罫線抽出、罫線選択、仮想罫線作成等の表情報抽出機能を実現するプログラムが記録されている。 また、スキャナなどの画像入力手段から入力された画像は一時的にハードウエアなどに格納される。そして、該プログラムが起動されると、一時的に保存された画像データが読み込まれ、入力画像中の表情報抽出処理を実行し、その処理結果をディスプレイなどに出力するようになっている。、【0025】

【発明の効果】請求項1に対応する効果:画像上の表領域から罫線を抽出するとともに、不要な罫線を除外する一方、不足する罫線を補ってフレームを作成できるので、例えば罫線の一部が欠けているような場合でも、表の構造をより精度良く抽出することができる。

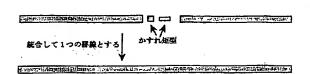
【0026】請求項2に対応する効果:請求項1に対応する効果に加え、分断された罫線の間にある画素の集まり、罫線の密度等の情報から、罫線の分断がかすれによるものか否かを判定することができるので、かすれた罫線を正確に抽出することできる。

【0027】請求項3に対応する効果:請求項1に対応する効果に加え、抽出された罫線が文字矩型によって包含されているか否かで罫線か否かを判断するようにした 30ので、誤って文字罫線と誤認して抽出することを防止することができる。

【0028】請求項4に対応する効果:請求項1に対応する効果に加え、水平罫線と垂直罫線が互いに一度も交わらない、または端同士が近接することのない罫線を抽出し、それらを表を構成する罫線からは除外して罫線選択するので、罫線抽出に当たって構造解析に不要な罫線を抽出しないようにすることができる。

【0029】請求項5に対応する効果:請求項1に対応 する効果に加え、表抽出に必要な仮想罫線を作成できる 40 ため、より正確な表領域の抽出ができる。

【図3】



۶

【0030】請求項6及び7に対応する効果:請求項5 に対応する効果に加え、フレーム作成に必要な仮想罫線 を容易に得ることができ、従って、正確な表領域を容易 に抽出することができる。

【0031】請求項8に対応する効果:表情報の抽出を ソフトウエアで実現するようにしたため、例えばマイコ ン等のハードウエア上で容易に動作させることができ る。

コンピュータ読み取り可能な記録媒体には、本発明の罫 【0032】請求項9に対応する効果:請求項8のソフ 線抽出、罫線選択、仮想罫線作成等の表情報抽出機能を 10 トウエアを媒体に記録したため、例えば、マイコン等で 実現するプログラムが記録されている。 また、スキャ 動作させるに際に取扱いが容易である。

【図面の簡単な説明】

【図1】 本発明の表情報抽出を行う装置全体を示すブロック図である。

【図2】 本発明の表情報抽出装置の処理フローを示す。 ブロック図である。

【図3】 本発明の分断された罫線の補完の一例を説明するための図である。

【図4】 本発明の分断された罫線の補完の他の例を説明するための図である。

【図5】 本発明の文字と罫線との識別を説明するための図である。

【図6】 本発明の罫線選択を説明するための図である。

【図7】 本発明の仮想罫線の作成の一例を説明するための図である。

【図8】 本発明の仮想罫線の作成の他の例を説明するための図である。

【図9】 本発明の仮想罫線作成部によって得られた仮 想罫線の一例を示す図である。

【図10】 本発明の仮想罫線作成部によって得られた 仮想罫線の他の例を示す図である。

【図11】 本発明をソフトウェアによって実施する場合に使用されるコンピュータシステムの一例を示す図である。

【符号の説明】

1…表情報抽出装置、2…スキャナ、3…画像入力部、4…画像メモリ、5…データメモリ、6…表データ、7 …抽出された罫線、8…外接矩型、101…画像圧縮 部、102…罫線抽出部、103…罫線選択部、104 …仮想罫線作成部、105…フレーム作成部。

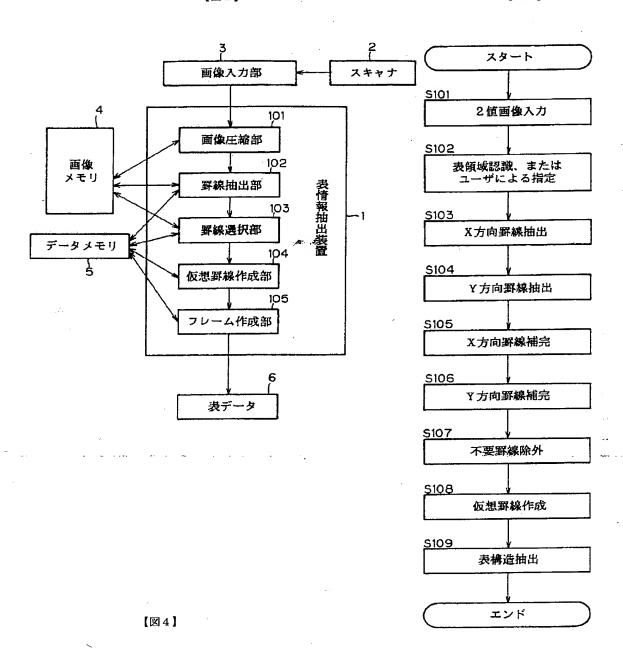
【図5】

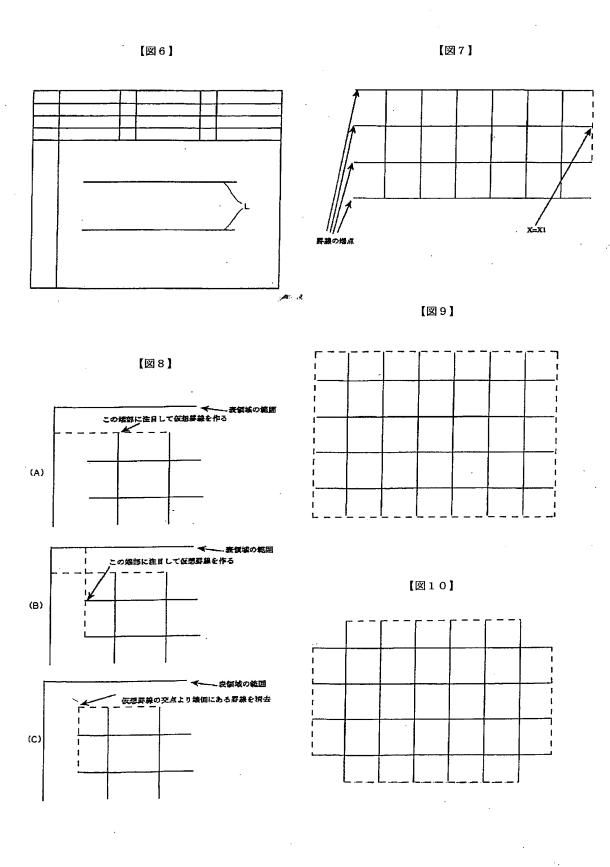


【図1】

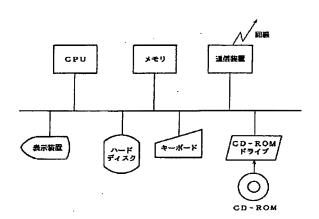
.c

【図2】





【図11】



Ar. 3